Rev Esp Cardiol. 2019;72(Supl 1): 114

Revista Española de Cardiología

5007-7. INTELIGENCIA ARTIFICIAL FRENTE A ESTADÍSTICA CLÁSICA EN LA PREDICCIÓN DE CARDIOVERSIÓN ESPONTÁNEA, FARMACOLÓGICA, ELÉCTRICA Y RECURRENCIA DE FIBRILACIÓN AURICULAR

Jean Carlos Núñez García[1], Antonio Sánchez-Puente[2], Jesús Sampedro Gómez[3], Víctor Vicente Palacios[1], Pedro Ignacio Dorado Díaz[3], Juan Carlos Castro Garay[4], David González Calle[1], Marta Alonso Fernández de Gatta[1], Javier Jiménez Candil[1], Jendri Manuel Pérez Perozo[1], Fabián Blanco Fernández[4], Milena Antúnez Ballesteros[4], Mónica García Monsalvo[4] y Pedro Luis Sánchez Fernández[1], del [1]Complejo Asistencial Universitario de Salamanca, Salamanca, [2]Instituto de Investigación Biomédica de Salamanca IBSAL, Salamanca y [3]Centros de Investigación Biomédica en Red CIBER, Salamanca.

Resumen

Introducción y objetivos: Con el fin de evitar procedimientos y fármacos inútiles o innecesarios, se han identificado mediante métodos estadísticos clásicos (MEC), múltiples factores clave para el desarrollo de modelos predictivos del éxito de la cardioversión eléctrica (CVE), espontánea (CVe), farmacológica (CVF) y recurrencia de fibrilación auricular (RFA). El *machine learning* (ML) provee herramientas que mejoran la estratificación de pacientes que ofrecen los MEC, sin embargo, no se han publicado resultados positivos de ML en este contexto. El objetivo de este estudio es comparar la predicción de CVe, CVF, CVE y RFA a 6 meses mediante ML frente a modelos predictivos establecidos creados con MEC.

Métodos: Se han ajustado modelos de ML independientes para cada evento (CVe, CVF, CVE y RFA), escogiendo las variables más discriminantes de los distintos eventos mediante minería de datos. Para validar los ajustes se empleó una validación cruzada de 10 subconjuntos repetida 10 veces. Finalmente, se compararon los resultados con 2 escalas publicadas y creadas con MEC (escalas HATCH y CHA_2DS_2-VASc) frente a ML.

Resultados: A partir de una base con 320 CVEs, se identificaron múltiples variables discriminantes para cada modelo de ML (tabla). La predicción de los eventos mediante las escalas HATCH y CHA_2DS_2-VASc fue insuficiente salvo en la predicción de CVe (AUC CVe 0,68 y 0,66; AUC CVF 0,55 y 0,53; AUC CVe o CVF 0,55 y 0,53; AUC CVE 0,53 y 0,48; y AUC RFA 0,56 y 0,54). El algoritmo de clasificación mediante ML de mayor rendimiento variaba en función del evento a predecir: Random Forest para CVe, CVe o CVF y RFA (AUC 0,82, 0,78 y 0,71); regresión logística mediante ML para CVF (AUC 0,77); y XGBoost para CVE (AUC 0,62). Las diferencias encontradas entre los modelos de ML y los MEC fueron estadísticamente significativas. En la figura se muestra la comparación de las curvas ROC para cada evento.

Curvas ROC Machine Learning, *HATCH y CHA2DSVASc*.

Conclusiones: Describimos el primer modelo predictivo mediante técnicas de ML con resultados positivos en este contexto. En nuestro medio, el ML supera el rendimiento de escalas creadas con estadística clásica publicados en revistas de impacto.